

NHẬN DẠNG HÀNH ĐỘNG HÀNG NGÀY CỦA CON NGƯỜI DỰA VÀO CẢM BIẾN GIA TỐC TRÊN ĐIỆN THOẠI THÔNG MINH

Lê Hồng Lam¹, Cao Ngọc Ánh², Nguyễn Hoài Nam³, Nguyễn Đức Nhân⁴, Trần Thủy Bình⁴, Nguyễn Hà Nam⁵

¹Khoa Điện tử, Trường Đại học Sư phạm Kỹ thuật Vinh

²Trường Đại học Kinh tế - Kỹ thuật công nghiệp

³Cục Công nghệ thông tin, Bộ Giáo dục và Đào tạo

⁴Khoa Viễn thông 1, Học viện Công nghệ Bru chính viễn thông

⁵Viện Công nghệ thông tin, Đại học Quốc gia Hà Nội

lehonglam.skv@gmail.com, cnanh@uneti.edu.vn, nam.moet@gmail.com, nhannd@ptit.edu.vn,
tran.binh95@gmail.com, namnh@vnu.edu.vn

TÓM TẮT: Nhận dạng chính xác hoạt động hàng ngày của con người luôn là một chủ đề thu hút sự chú ý trong nghiên cứu và là một nhiệm vụ khó khăn, đặc biệt khi số lượng hoạt động lớn trong đó có cả các hoạt động bất thường như ngã. Nhờ sự phổ biến rộng rãi việc sử dụng điện thoại thông minh, bài toán nhận dạng hoạt động dựa vào dữ liệu thu được từ cảm biến trên điện thoại thông minh người dùng đang được quan tâm nhiều. Bài báo này sẽ khảo sát đánh giá một mô hình nhận dạng các hoạt động hàng ngày bao gồm cả các hành vi bất thường dựa trên dữ liệu cảm biến gia tốc của điện thoại thông minh. Ảnh hưởng kích thước cửa sổ trượt và các tập thuộc tính khác nhau lên độ chính xác phân lớp từng hành động cũng sẽ được khảo sát đánh giá trong bài báo này. Tập thuộc tính khác nhau được xem xét dựa trên các miền khác nhau bao gồm tập thuộc tính miền thời gian, tập thuộc tính miền tần số và tập thuộc tính Hjorth cùng các tổ hợp giữa các miền để lựa chọn tập thuộc tính phù hợp nâng cao kết quả phân lớp. Thực nghiệm được tiến hành trên các bộ phân loại khác nhau bao gồm Random Forest (RF), SVM, kNN và kết quả thu được cho thấy giải thuật Random Forest đạt được kết quả nhận dạng tốt nhất.

Từ khóa: Nhận dạng hành động, cảm biến gia tốc trên smartphone, mô hình phân lớp Random Forest, tập thuộc tính.

I. GIỚI THIỆU

Điện thoại thông minh đã trở nên phổ biến ở nhiều nước trên thế giới và Việt Nam, do đó nó trở thành một công cụ hữu ích cho nhận dạng hành động hàng ngày của người dùng nhờ thu thập các dữ liệu từ các cảm biến được tích hợp. Với sự gia tăng dân số cao tuổi ở nhiều nước trên thế giới hiện nay, hệ thống nhận dạng hành động đặc biệt là các hành động bất thường của con người xảy ra do ngã, đột quỵ, bị va đập mạnh hoặc mất kiểm soát... càng được quan tâm nghiên cứu trong những năm gần đây để hỗ trợ bản thân người cao tuổi và người chăm sóc trong cuộc sống hàng ngày. Nhận dạng hành động hàng ngày của con người dựa trên mô hình học máy đã được quan tâm nghiên cứu từ lâu và được ứng dụng trong nhiều lĩnh vực khác nhau như giao thông, giám sát môi trường và chăm sóc y tế [1], [2]. Trong cuộc sống hàng ngày với nhiều hoạt động, các hành vi bất thường có thể rất đa dạng, tuy nhiên hành vi bất thường do ngã vẫn được quan tâm chú ý nhận dạng nhiều nhất vì hậu quả của ngã đem lại thường nghiêm trọng đặc biệt đối với người già.

Ravi và cộng sự [3] đã phân loại 8 hoạt động khác nhau của con người bằng cách sử dụng gia tốc kế. Shoaib và cộng sự [4] đã sử dụng cả điện thoại thông minh và đồng hồ thông minh để xác định các hoạt động hàng ngày khác nhau của con người. Họ đã sử dụng mô hình phân lớp cây quyết định C4.5, kNN và SVM. Sag bas và Ballı [5] đã so sánh sự thành công của phương pháp Naive Bayes và kNN trong việc phân loại các hoạt động của con người bằng cách sử dụng gia tốc kế và cảm biến đếm bước chân của đồng hồ thông minh. Trong nghiên cứu được thực hiện bởi Parkka và cộng sự [6] hoạt động hàng ngày đã được xác định với các cảm biến gia tốc kế và con quay hồi chuyển gắn ở hông, cổ tay và cổ chân, những kết quả đạt được ở ba vị trí này đã được so sánh. Riboni và Bettini [7] đã sử dụng các mạng Bayes, C4.5, hồi quy logistic, Naive Bayes và SVM để phân loại dữ liệu thu được từ điện thoại thông minh Android và thiết bị đeo được của Sun microsystems. Trong bài báo này, nhóm tác giả đã lựa chọn điện thoại thông minh để tiến hành các nghiên cứu vì tính phổ biến của nó.

Nhận diện đúng các mẫu hành vi bất thường liên quan đến ngã khi chỉ sử dụng dữ liệu cảm biến trên điện thoại thông minh là một thách thức lớn. Có nhiều yếu tố tác động dẫn đến khả năng ngã và có thể được phân thành các yếu tố bên trong liên quan đến hành vi, trạng thái sức khỏe con người và các yếu tố bên ngoài liên quan đến môi trường [8], [9]. Việc nhận diện được càng nhiều các mối liên kết giữa các yếu tố này sẽ càng giúp xác định được rõ mức độ rủi ro dẫn đến ngã. Với chỉ dữ liệu thu từ các cảm biến chuyển động trên điện thoại thông minh thì yếu tố môi trường không được xác định sẽ tạo ra thách thức lớn để đánh giá được mức độ rủi ro ngã. Do vậy, việc cần thiết là phải xác định được rõ các pha đặc trưng trong dáng đi của con người, đặc biệt là người già, qua đó xác định được các tham số đặc trưng cho từng pha và sự biến đổi các tham số đó theo thời gian ảnh hưởng đến khả năng ngã. Việc xây dựng mô hình nhận diện hành vi bất thường cũng cần xem xét các phương pháp trích xuất đặc trưng khác nhau: trích rút đặc trưng miền thời gian, trích rút đặc trưng miền tần số, miền biến đổi hoặc tham số Hjorth. Xác định được tập các đặc trưng tiêu biểu sẽ có vai trò vô cùng quan trọng cho phép thuật toán phân loại có thể nhận diện các mẫu hành vi bất thường của con người với độ chính xác cao trong bối cảnh hoạt động sống hàng ngày tại Việt Nam.

Tính mới của nghiên cứu này nằm đề xuất tập thuộc tính đặc trưng dựa trên miền thời gian và miền tần số nhằm biến đổi dữ liệu cảm biến thành dữ liệu đặc trưng phục vụ cho nhận dạng hành động và hành vi bất thường. Kết quả độ

đo sau khi phân lớp dữ liệu được sử dụng để đánh giá, lựa chọn tập thuộc tính. Trong đó, sử dụng tham số Hjorth cho các đại lượng khác nhau nhằm thu được các thuộc tính phù hợp để biến đổi dữ liệu cảm biến thành dữ liệu đặc trưng. Tập thuộc tính đặc trưng phù hợp sẽ sử dụng làm cơ sở cho việc xây dựng hệ thống nhận dạng bằng các phương pháp phân lớp RF, kNN và SVM. Kết quả thu được cho thấy giải thuật RF có kết quả nhận dạng tốt nhất.

Cấu trúc của bài báo ở phần II giới thiệu sơ đồ hệ thống nhận dạng, các bước tiền xử lý dữ liệu, thiết lập cửa sổ dữ liệu và tập thuộc tính đặc trưng. Phần III trình bày quá trình thực nghiệm và đánh giá mô hình. Phần IV sẽ đưa ra các kết luận và đề xuất hướng nghiên cứu trong tương lai.

II. MÔ HÌNH NHẬN DẠNG

A. Sơ đồ hệ thống nhận dạng

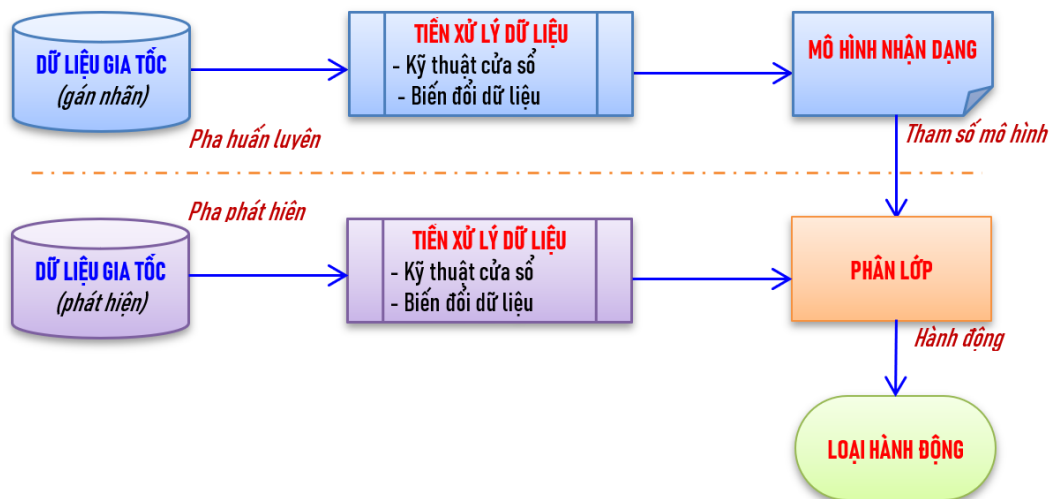
Hệ thống nhận dạng hành động thực hiện việc thu thập, tiền xử lý dữ liệu, biến đổi để có tập dữ liệu đặc trưng dựa trên tập thuộc tính được đề xuất. Từ một số nghiên cứu đã có cho thấy, kích thước cửa sổ dữ liệu sử dụng trong nhận dạng được cố định đối với tất cả các đối tượng. Điều này gặp phải nhiều khó khăn khi các hành động, hành vi cần nhận dạng có những đặc điểm, tính chất khác nhau. Do đó, hệ thống nhận dạng dựa vào dữ liệu đặc trưng được biến đổi bằng tập thuộc tính đề xuất với cửa sổ dữ liệu khác nhau theo từng loại hành động. Các kích thước cửa sổ được lựa chọn dựa trên đánh giá độ đo AUC khi phân lớp dữ liệu.

Dữ liệu cảm biến gia tốc thu được từ điện thoại gồm các điểm dữ liệu là những vectơ gồm ba số thực tương ứng trên ba trục X, Y, Z của hệ trục tọa độ thiết bị. Chuỗi tín hiệu cảm biến gia tốc với các điểm được thêm vào theo thời gian có tính chất của dữ liệu chuỗi thời gian. Vì một chuỗi thời gian dạng luồng bao gồm một số lớn các giá trị. Do các nhân tố chủ quan, khách quan cũng như sự khác nhau về chủng loại thiết bị, tần số lấy mẫu khi thu dữ liệu sẽ cho các chuỗi dữ liệu sẽ khác nhau. Vì vậy, cần sử dụng những kỹ thuật tiền xử lý cũng như phân đoạn cửa sổ tín hiệu có kích thước phù hợp sao cho thông tin về đối tượng nhận dạng nhiều nhất trên cửa sổ dữ liệu đó.

Kỹ thuật cắt và chồng dữ liệu được sử dụng để phân đoạn một chuỗi dữ liệu cảm biến liên tục thành các cửa sổ có kích thước là W. Cắt chồng dữ liệu là cách lấy lại một số điểm dữ liệu của cửa sổ trước đó làm một thành phần cho cửa sổ hiện tại. Kỹ thuật này được sử dụng trong nhiều nghiên cứu đã công bố về nhận dạng hành động, hành vi thông qua dữ liệu cảm biến như [10], [11], [12], [13].

Dựa vào các cửa sổ dữ liệu, những phương pháp trích xuất, biến đổi dữ liệu được áp dụng để đưa ra những giá trị đặc trưng của các đối tượng cần nhận dạng. Tiếp đến là áp dụng những thuật toán nhận dạng phù hợp để thu được kết quả mong muốn.

Hệ thống nhận dạng các hoạt động hàng ngày bao gồm cả các hành vi bất thường dựa trên dữ liệu cảm biến gia tốc của điện thoại thông minh được xây dựng và biểu diễn như Hình 1:



Hình 1. Hệ thống nhận dạng các hoạt động hàng ngày

Hệ thống nhận dạng bao gồm 2 pha: Pha thứ nhất, sử dụng dữ liệu gia tốc có gán nhãn các loại hành động cơ bản đã được thu thập và xác định trước. Các kỹ thuật tiền xử lý dữ liệu được sử dụng kết hợp với tập thuộc tính đặc trưng được đề xuất để xây dựng tập dữ liệu đặc trưng qua đó xây dựng mô hình phát hiện cho hệ thống bằng phương pháp nhận dạng. Pha thứ hai, nhận dạng các hoạt động hàng ngày dựa trên dữ liệu cảm biến thu được từ điện thoại của các tình nguyện viên. Các kỹ thuật biến đổi dữ liệu, trích xuất đặc trưng được áp dụng để tạo mẫu dữ liệu phát hiện, phát hiện nhãn của mẫu dữ liệu này bằng bộ phân lớp.

Mỗi loại hành động, hành vi có tính chất, đặc trưng khác nhau nên kích thước cửa sổ dữ liệu tương ứng cũng khác nhau. Việc tìm một cửa sổ có kích thước phù hợp chứa đủ các thông tin của tất cả các đối tượng cần phân loại,

nhận dạng sẽ gặp nhiều khó khăn dẫn đến cần phải khảo sát và lựa chọn các kích thước phù hợp với từng nhãn lớp. Trong kỹ thuật cửa sổ dữ liệu, kết quả khảo sát, tối ưu nhận được là các giá trị kích thước cửa sổ và chồng dữ liệu phù hợp theo từng nhãn lớp hành động.

B. Các kỹ thuật phân lớp sử dụng trong mô hình

Ngày nay, cùng với sự tăng nhanh về dung lượng và chủng loại dữ liệu. Các kỹ thuật, mô hình cũng được nghiên cứu cải tiến để đáp ứng được những yêu cầu trong bối cảnh mới đặt ra. Mô hình phân lớp là một trong những mô hình phổ biến, được áp dụng trong nhiều bài toán khác nhau. Nhiều mô hình phân lớp có thể sử dụng trong nhận dạng hoạt động bao gồm cây quyết định, phương pháp Naïve Bayes, kNN, mạng nơron, mô hình Markov và kết hợp các bộ phân lớp [14]. Trong nghiên cứu này, nhóm tác giả sử dụng các mô hình phân lớp: Rừng ngẫu nhiên RF, thuật toán phân lớp máy véc-tơ hỗ trợ SVM và thuật toán phân lớp kNN để tiến hành thực nghiệm. Phương pháp phân lớp phi tham số kNN rất phổ biến trong hoạt động nhận dạng; máy véc-tơ hỗ trợ SVM đã được chứng minh là có độ chính xác trong dự báo rất tốt trong các ứng dụng, bao gồm cả nhận dạng hoạt động [15].

Thuật toán kNN là một trong những phương pháp học có giám sát "Supervised Learning" tức là dựa trên biến mục tiêu đã được xác định trước đó, thuật toán sẽ xem xét dữ liệu đã chứa biến mục tiêu (đã phân loại) để "học và tìm ra những biến d có thể tác động đến biến mục tiêu. Khi đưa một phần tử dữ liệu mới, giải thuật sẽ tìm k phần tử dữ liệu láng giềng gần nó nhất (k nearest neighbors), sau đó dựa trên nhãn (lớp) của các láng giềng này mà nó sẽ quyết định nhãn (lớp) của phần tử dữ liệu mới là thuộc lớp nào. Trường hợp đơn giản nhất, giả sử chỉ tìm một phần tử gần phần tử mới nhất, nhãn của phần tử mới sẽ được gán là nhãn của phần tử tìm được. Để tìm các phần tử láng giềng gần nhất cần định nghĩa độ đo nào đó, một trong các độ đo điển hình là độ đo khoảng cách Euclide [16-tr255]. Giải thuật kNN còn gọi là "Lazy learning method" vì tính đơn giản của nó, quá trình training không quá phức tạp để hoàn thành mô hình (tất cả các dữ liệu đào tạo có thể được sử dụng để kiểm tra mô hình kNN). Điều này làm cho việc xây dựng mô hình nhanh hơn nhưng giai đoạn thử nghiệm chậm hơn và tốn kém hơn về mặt thời gian và bộ nhớ lưu trữ, đặc biệt khi bộ dữ liệu lớn và phức tạp với nhiều biến khác nhau. Trong trường hợp xấu nhất, kNN cần thêm thời gian để quét tất cả các điểm dữ liệu và việc này sẽ cần nhiều không gian bộ nhớ hơn để lưu trữ dữ liệu. Ngoài ra, kNN không cần dựa trên các tham số khác nhau để tiến hành phân loại dữ liệu, không đưa ra bất kỳ kết luận cụ thể nào giữa biến đầu vào và biến mục tiêu, mà chỉ dựa trên khoảng cách giữa data point cần phân loại với data point đã phân loại trước đó. Đây là một đặc điểm cực kỳ hữu ích vì hầu hết dữ liệu trong thế giới thực tại không thực sự tuân theo bất kỳ giả định lý thuyết nào ví dụ như phân phối chuẩn trong thống kê.

Thuật toán máy véc-tơ hỗ trợ (Support Vector Machine - SVM) là một thuộc lớp giải thuật phân lớp thống kê. Đây là một mô hình học máy có giám sát thường được dùng trong các bài toán phân loại nhị phân. SVM có khả năng xử lý cả dữ liệu tuyến tính và dữ liệu không tuyến tính. Bản chất của giải thuật này là xây dựng một siêu phẳng để phân chia dữ liệu thành 2 nửa. Giải thuật này coi mỗi dữ liệu huấn luyện ứng với một điểm trong không gian N chiều, mô hình sẽ tìm một siêu phẳng N - 1 chiều tốt nhất chia đôi tập điểm sao cho các dữ liệu cùng lớp thuộc cùng một phần không gian. Tốt nhất ở đây theo nghĩa siêu phẳng có lề lớn nhất, với lề là khoảng cách từ điểm gần nhất (ở mỗi lớp) tới siêu phẳng. Trong trường hợp nếu dữ liệu là không tuyến tính, nó sẽ sử dụng một hàm nhân (kernel function) để chuyển đổi tập dữ liệu ban đầu sang một không gian mới có số chiều lớn hơn để xử lý [16-tr245].

Thuật toán Rừng ngẫu nhiên (Random Forest) dựa trên kỹ thuật học kết hợp, là một phương pháp tạo ra nhiều bộ phân lớp và kết hợp các kết quả của chúng. Rừng ngẫu nhiên sẽ tạo ra nhiều cây quyết định mà cụ thể là thuật toán phân lớp cây phân loại và hồi quy (CART) [17], sử dụng kỹ thuật bagging. Mỗi cây được huấn luyện sử dụng một mẫu dữ liệu mới (bootstrap), lấy từ tập dữ liệu gốc ban đầu và tìm kiếm trong một nhóm nhỏ ngẫu nhiên các thuộc tính trong tập thuộc tính đầu vào để phân chia cho mức tiếp theo của cây. CART là cây quyết định nhị phân, được tạo nên bằng cách liên tiếp phân chia dữ liệu tại mỗi nút thành các nút nhỏ hơn, bắt đầu từ nút gốc chứa toàn bộ dữ liệu đầu vào. Nhờ chia nhỏ không gian tìm kiếm theo cách này, việc phân loại được thực hiện rất nhanh chóng kể cả đối với trường hợp không gian thuộc tính lớn. Tham số đầu vào của hàm phân chia bao gồm các thuộc tính được chọn trong mỗi lần phân chia. Rừng ngẫu nhiên không hạn chế số lượng cây tạo ra cũng như sự mở rộng của cây. Tuy nhiên, cần chọn số cây sẽ được sinh để đảm bảo mỗi một thuộc tính sẽ được kiểm tra một vài lần. Để xây dựng tập huấn luyện và phương pháp kiểm tra, kỹ thuật "out-of-bag" được sử dụng trong rừng ngẫu nhiên. Giống CART, rừng ngẫu nhiên sử dụng độ đo Gini cho độ pha tạp thông tin (impurity) để tìm ra tập phân chia tốt nhất, là tập có độ pha tạp thông tin tối thiểu tại mọi nút [18]. Độ pha tạp thông tin Gini là một cách đo phân bố nhãn của các lớp trong một nút, lấy giá trị trong khoảng [0, 1], trong đó giá trị 0 có được khi mọi phần tử trong một nút đều thuộc cùng một lớp.

C. Tập thuộc tính đặc trưng

Trong miền thời gian, một số đại lượng thống kê cơ bản được sử dụng lựa chọn làm các thuộc tính đặc trưng như giá trị trung bình, phương sai và độ lệch chuẩn. Bên cạnh đó, một số tính năng khác trong miền thời gian như độ lệch mẫu (độ lệch giữa các giá trị mẫu cực đại và cực tiểu), tương quan tín hiệu và hệ số tương quan, tỉ lệ đỉnh trên trung bình (PAR), diện tích độ lớn tín hiệu (SMA), độ lớn véc-tơ tín hiệu (SVM) và tín hiệu vi sai độ lớn véc-tơ (DSVM) [19].

Quá trình hoạt động của con người có sự thay đổi gia tốc nên các thuộc tính trong miền thời gian có ý nghĩa và hàm chứa những thông tin hữu ích khi phân tích các hành động, hành vi. Ngoài ra, cũng cần phân tích những thuộc tính

hỗ trợ từ các miền thông tin khác. Để lựa chọn được tập thuộc tính đặc trưng phù hợp, cần kết hợp các thuộc tính trên miền thời gian, miền tần số và các tham số Hjorth. Tuy nhiên, để đánh giá được sự hỗ trợ của các tập thuộc tính. Chúng tôi lần lượt đánh giá và kết hợp với nhau nhằm làm rõ sự ảnh hưởng của các tham số.

Tập thuộc tính (T): Tập thuộc tính này bao gồm các thuộc tính trên miền thời gian đó là giá trị trung bình, thuộc tính phương sai, thuộc tính hiệp phương sai, thuộc tính độ lệch chuẩn, thuộc tính độ tương quan, giá trị điểm cắt không, thuộc tính độ đo hiệu dụng trên từng cửa sổ dữ liệu. Cùng với các thuộc tính tỉ lệ đỉnh trên trung bình (Pick Average Ratio) trên các trục X, Y, Z của cảm biến gia tốc nhằm tăng thêm hiệu quả nhận dạng các hành động giao thông. Kết hợp với 4 thuộc tính diện tích độ lớn tín hiệu (SMA) [19] cùng với thuộc tính độ lớn véctơ tín hiệu vi sai DSVM [19], thuộc tính về giá trị trung bình, phương sai và giá trị ước tính cho tốc độ biến thiên góc quay. Tổng số thuộc tính trong miền thời gian ở tập T là 34 thuộc tính.

Tập thuộc tính (F): Tập thuộc tính này bao gồm các thuộc tính trên miền tần số của tín hiệu cảm biến gia tốc thu được trong các hoạt động. Bên cạnh đó, sự thay đổi về tín hiệu dẫn đến thay đổi về giá trị năng lượng, nên các đại lượng liên quan đến năng lượng tín hiệu cũng như độ đo Entropy được lựa chọn nhằm trợ giúp nhận dạng các hành động, hành vi khác nhau. Số lượng các thuộc tính trong tập F này là 7 thuộc tính.

Tham số Hjorth (H): Được đề xuất sử dụng chủ yếu trong lĩnh vực phân tích tín hiệu tin sinh học [20][21]. Đặc trưng của tham số này có tính chất thống kê của tín hiệu trong miền thời gian gồm tính hoạt động, tính di động và tính phức hợp của tín hiệu. Để nhận dạng hành động và hành vi, nhóm tác giả đề xuất sử dụng các tham số này đối với các đại lượng góc xoay cũng như đại lượng trên các trục khác nhau của dữ liệu cảm biến gia tốc. Tập thuộc tính từ tham số Hjorth ký hiệu là H bao gồm 18 thuộc tính được sử dụng cho thực nghiệm.

III. THỰC NGHIỆM ĐÁNH GIÁ MÔ HÌNH

A. Tổng quan về bộ dữ liệu

Trong nghiên cứu này, nhóm tác giả sử dụng bộ dữ liệu cảm biến điện thoại MobiAct để tiến hành xây dựng hệ thống nhận dạng. MobiAct là một bộ dữ liệu đã công bố rộng rãi có thể tải về miễn phí từ địa chỉ www.bmi.teicrete.gr. Bộ dữ liệu này bao gồm 4 loại ngã khác nhau và 12 trạng thái hoạt động hàng ngày (ADL - Activities of Daily Living) khác nhau được 66 tình nguyện viên thực hiện với hơn 9879 thử nghiệm được thu thập từ 3 loại cảm biến bao gồm gia tốc kế (acc - accelerometer), con quay hồi chuyển (gyro - gyroscope) và cảm biến góc nghiêng (ori - orientation) của điện thoại thông minh Samsung Galaxy S3 [22]. Bộ dữ liệu MobiAct phù hợp để điều tra cả nhiệm vụ phát hiện/nhận dạng sự té ngã và nhận dạng hoạt động của con người. Bảng 1 và 2 tóm tắt tất cả các hoạt động hàng ngày và hành động ngã được ghi lại (và mã hoạt động), số lượng, thời gian thử nghiệm và mô tả tóm tắt về các hoạt động.

Bảng 1. Các hoạt động hàng ngày (ADL)

TT	Nhãn	Hoạt động	Thử nghiệm	Thời gian	Mô tả
1	STD	Đứng	1	5 phút	Đứng với với cử động nhẹ nhàng
2	WAL	Đi bộ	1	5 phút	Đi bộ bình thường
3	JOG	Chạy bộ	3	30 giây	Chạy bộ
4	JUM	Nhảy	3	30 giây	Nhảy liên tục
5	STU	Lên cầu thang	6	10 giây	Đi lên cầu thang (10 bậc)
6	STN	Xuống cầu thang	6	10 giây	Đi xuống cầu thang (10 bậc)
7	SCH	Đứng chuyển sang ngồi	6	6 giây	Chuyển tiếp từ đứng sang ngồi (ngồi trên ghế)
8	SIT	Ngồi trên ghế	1	1 phút	Ngồi trên ghế với những cử động nhẹ nhàng
9	CHU	Ngồi chuyển sang đứng	6	6 giây	Chuyển tiếp từ ngồi sang đứng (đứng lên từ ghế)
10	CSI	Bước vào xe hơi	6	6 giây	Bước vào trong xe
11	CSO	Bước ra khỏi xe hơi	6	6 giây	Bước ra khỏi xe hơi
12	LYI	Nằm	12	-	Hoạt động được thực hiện ở khoảng thời gian nằm sau ngã

Bảng 2. Các trạng thái ngã (Falls)

TT	Nhãn	Hoạt động	Thử nghiệm	Thời gian	Mô tả
10	FOL	Ngã về phía trước	3	10 giây	Ngã về phía trước khi đang đứng, sử dụng tay để chống ngã
11	FKL	Ngã gập đầu gối	3	10 giây	Ngã về phía trước khi đang đứng, đầu gối tiếp xúc đầu tiên.
12	BSC	Ngã từ ghế	3	10 giây	Ngã ngửa trong khi đang ngồi trên ghế
13	SDL	Ngã nghiêng	3	10 giây	Ngã sang một bên khi đang đứng, gập chân

Thành công của phương pháp đề xuất cũng đã được đánh giá với các tiêu chí đánh giá khác nhau. Ở giai đoạn này, khu vực dưới đường cong (AUC), độ chính xác phân loại (Acc) và F-measure đã được sử dụng. Các tiêu chí này

thường được ưa thích trong các nghiên cứu nhận dạng hành động của con người và các vấn đề phân loại [7][23][24]. Mục đích của việc sử dụng các phương pháp khác nhau trong thực nghiệm là để nhận được kết quả phân lớp tốt nhất.

B. Kết quả thực nghiệm

1. Ảnh hưởng của tập thuộc tính đặc trưng

Để đánh giá, lựa chọn tập thuộc tính có kết quả phân loại tốt nhất, nhóm nghiên cứu tiến hành đánh giá trên từng tập thuộc tính H, T, F, sau đó tiến hành kết hợp các tập thuộc tính với nhau sẽ được TF, TH, TFH.

Thông qua thực nghiệm, nhằm đánh giá tính chất của các thuộc tính phù hợp, cửa sổ dữ liệu được lựa chọn là 5 giây đối với tất cả hành động, cùng với tỉ lệ chồng dữ liệu là 50 %. Một số thuật toán phân lớp thông dụng như RF, kNN, SVM với các tham số mặc định trong phần mềm weka được lựa chọn như trong Bảng 3 để tiến hành thực nghiệm. Số lượng các thuộc tính trên mỗi tập được biểu diễn như Bảng 4. Phương pháp đánh giá sử dụng kiểm tra chéo - 10 fold.

Bảng 3. Tham số của các thuật toán phân lớp sử dụng cho thực nghiệm

TT	Thuật toán	Tham số
1	RF	Số lượng cây trong RF, I = 100; Xác nhận chéo 10 lần (cross-validation folds = 10), Kích thước gió (%) so với tập huấn luyện P = 100; không giới hạn độ sâu tối đa của cây.
3	k- NN	Số lượng láng giềng gần nhất k = 1; Không có giới hạn về số lượng phiên bản huấn luyện W = 0; Thuật toán tìm kiếm láng giềng gần nhất để sử dụng (Mặc định: weka.core.neighboursearch.LinearNNSearch).
5	SVM	Tham số độ phức tạp C = 1,0; Số lần xác thực chéo: sử dụng dữ liệu huấn luyện; Phương pháp hiệu chuẩn sử dụng mô hình hồi quy logistic đa thức.

Bảng 4. Các tập thuộc tính dùng để khảo sát cho hệ thống nhận dạng hành động

Miền, tham số Hjorth	Tên tập thuộc tính	Số lượng thuộc tính
Thời gian	T	34
Tần số	F	07
Hjorth	H	18
Thời gian + Tần số	TF	41
Thời gian + Hjorth	TH	52
Thời gian + Tần số + Hjrth	TFH	59

Thực nghiệm với các tập thuộc tính trên thu được các kết quả về độ chính xác Accuracy (Acc), AUC và F-measure như Bảng 5. Trong nghiên cứu này, F-measure được tính toán cho các hành vi ngã. Kết quả đưa ra trong Bảng 5 là giá trị trung bình của các hành động ngã đã giới thiệu ở Bảng 1.

Bảng 5. Kết quả phân lớp các hoạt động và hành vi ngã trên (Falls) các tập thuộc tính khác nhau

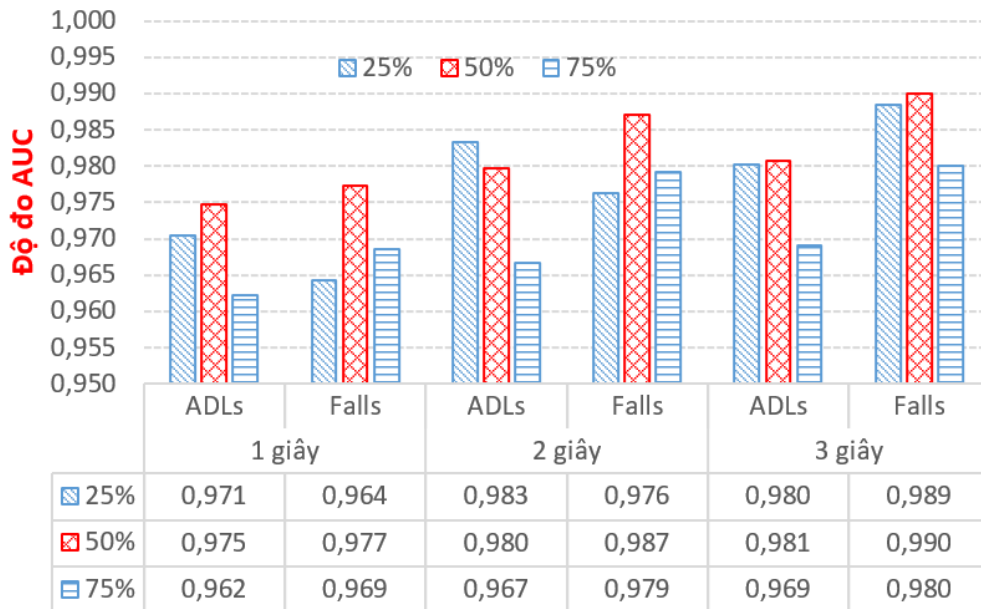
5s 50 %	Random Forest			SVM			kNN		
	Acc	F-measure	AUC	Acc	F-measure	AUC	Acc	F-measure	AUC
T	93,00 %	68,78 %	98,28 %	81,83 %	28,45 %	89,24 %	91,22 %	65,40 %	79,53 %
F	86,76 %	55,44 %	96,58 %	79,92 %	25,80 %	84,27 %	83,37 %	46,48 %	70,81 %
H	86,38 %	48,78 %	95,55 %	78,93 %	13,65 %	81,07 %	76,82 %	27,95 %	65,94 %
TF	93,91 %	72,40 %	98,36 %	82,17 %	31,28 %	89,69 %	91,37 %	68,05 %	80,21 %
TH	93,91 %	73,52 %	97,48 %	82,17 %	31,88 %	83,48 %	91,37 %	65,60 %	76,33 %
TFH	94,80 %	83,98 %	98,34 %	84,35 %	34,35 %	90,19 %	87,39 %	47,00 %	74,16 %

Bảng 5 cho thấy, kết quả phân lớp trên tập T có độ chính xác tốt hơn tập H và F nên các thuộc tính ở tập T được lấy làm thành phần chính khi khảo sát kết hợp thành ba tập thuộc tính để đánh giá đó là: TH, TF và TFH nhằm thu được một tập thuộc tính kết hợp tốt nhất cho nhận dạng hành động. Kết quả lựa chọn dựa trên AUC trong mô hình RF thu được tập thuộc tính TFH với kết quả cao nhất.

2. Ảnh hưởng của cửa sổ dữ liệu

Các hành động như đi bộ, chạy bộ, đi lên cầu thang, chạy, nhảy ... có những đặc điểm, chu kỳ khác nhau. Ban đầu, trong quá trình nghiên cứu, khi sử dụng kích thước cửa sổ cố định để nhận dạng các loại hành động bằng cửa sổ đó. Việc này dẫn đến sự khó khăn khi phải lựa chọn một kích thước cửa sổ phù hợp cho tất cả các loại hành động. Để giải quyết vấn đề này, nhóm nghiên cứu đã lựa chọn hướng tiếp cận khác khảo sát đánh giá, lựa chọn kích thước cửa sổ trên từng hành động dựa vào độ đo AUC nhằm chọn được các kích thước cửa sổ phù hợp, nâng cao độ chính xác phân lớp.

Các hành động xảy ra trong một hành vi bất thường diễn ra nhanh nên kích thước cửa sổ dữ liệu được lựa chọn khảo sát là 1 giây, 2 giây và 3 giây. Kết quả phân lớp bằng RF tương ứng với tập dữ liệu cắt bởi kích thước cửa sổ khác nhau, đánh giá bằng phương pháp kiểm chứng chéo 10 - fold thu được kết quả như Hình 2.



Hình 2. Kết quả độ đo AUC của tất cả các hành động và của hành động ngã

Từ kết quả thu được ở Hình 2, nhận thấy khả năng phát hiện hành vi bất thường kích thước cửa sổ $W = 3$ giây và chông dữ liệu 50 % là tốt nhất.

Phương pháp nhận dạng các hành động hàng ngày bằng các thuật toán phân lớp là một phương pháp phổ biến được nhiều nghiên cứu sử dụng. Tùy theo dữ liệu, yêu cầu của bài toán sẽ có những hệ thống nhận dạng được thiết kế khác nhau. Với tập thuộc tính như đã đề xuất, nhóm nghiên cứu đã thực nghiệm trên bộ dữ liệu MobiAct; kết quả thực nghiệm về phát hiện các hành động ngã trong nghiên cứu này cao hơn so với các phương pháp của một số nghiên cứu trên cùng bộ dữ liệu này như thống kê trong Bảng 6. Qua những kết quả đánh giá này cho thấy, hệ thống nhận dạng là phù hợp và có kết quả khả quan trong việc nhận dạng các hành động hàng ngày, đặc biệt là hành động ngã.

Bảng 6. Kết quả phương pháp nhận dạng trên tập thuộc tính đề xuất với phương pháp khác [22] trên cùng bộ dữ liệu MobiAct

Nghiên cứu	Kết quả phân của từng hành động ngã				Kết quả phân trung bình của các hành động ngã
	BSC	FKL	FOL	SDL	
Charikleia Chatzaki và cộng sự [22]	83,16 %	75,57 %	69,10 %	72,14 %	75,94 %
Phương pháp đề xuất	89,40 %	84,58 %	80,20 %	81,75 %	83,98 %

IV. KẾT LUẬN VÀ HƯỚNG NGHIÊN CỨU TIẾP THEO

Trong nghiên cứu này, nhóm tác giả đã tiến hành tìm hiểu, khảo sát tính chất của dữ liệu cảm biến, các kỹ thuật phân tích dữ liệu áp dụng cho loại dữ liệu đặc thù này. Sau đó, nhóm tiến hành nghiên cứu xây dựng tập thuộc tính đặc trưng nhằm nâng cao hiệu quả của mô hình nhận dạng hành động của con người bao gồm cả các hành vi bất thường. Dựa vào kết quả nhận dạng các hành động hàng ngày, nhóm tác giả đề xuất kỹ thuật phát hiện hành vi bất thường bằng cách phân đoạn cửa sổ dữ liệu của một hành động thường ngày thành các đoạn với kích thước cửa sổ đủ nhỏ và áp dụng phương pháp nhận dạng hành động với các cửa sổ dữ liệu này.

Phương pháp đề xuất đã được thử nghiệm và đánh giá kết quả dựa trên bộ dữ liệu MobiAct đã được công bố. Với bộ dữ liệu này, 11 hoạt động hàng ngày khác nhau của con người và 4 hành động ngã được phân loại. Thử nghiệm với kỹ thuật rừng ngẫu nhiên cho kết quả tốt nhất trong 03 kỹ thuật được sử dụng. Ngoài ra so sánh với kết quả của nhóm tác giả Charikleia Chatzaki, mặc dù kết quả tổng thể vẫn thấp hơn tuy nhiên tỷ lệ phát hiện các hoạt động ngã trong mô hình của bài báo này cao hơn khá nhiều (Bảng 6). Kết quả của nghiên cứu này có thể hữu ích trong việc phát hiện và ngăn chặn các hành động nguy hiểm như ngã của người già, hoặc các hành động không tốt cho sức khỏe của con người.

Trong thời gian tới, nhóm tác giả sẽ tiếp tục hoàn thiện và phát triển nghiên cứu theo hướng sử dụng thêm các dữ liệu khác thu thập từ cảm biến gia tốc, con quay hồi chuyển, cảm biến nhịp tim và cảm biến đếm bước chân của đồng hồ thông minh và điện thoại thông minh để nhận dạng các hành động của con người được phong phú hơn. Khi đó, các hoạt động như theo dõi chế độ dinh dưỡng của từng cá nhân, phát hiện các thói quen xấu có thể được theo dõi. Ngoài ra, có thể đưa ra các cảnh báo với những người như đi bộ bỏ tay trong túi, đi loạng choạng,....

V. TÀI LIỆU THAM KHẢO

- [1] Khan, W.Z., et al., “Mobile Phone Sensing Systems: A Survey”. *IEEE Communications Surveys & Tutorials*. 15(1): p. 402-427.
- [2] Mridul Khan, Sheikh I. Ahamed, Miftahur Rahman, Roger O. Smith, “A Feature Extraction Method for Real time Human Activity Recognition on Cell Phones”, *RESNA_ICTA Conference*, Toronto, ON, Canada, June 5-8, 2011.
- [3] Ravi N, Dandekar N, Mysore P, et al. “Activity recognition from accelerometer data”. *Am Assoc Artif Intel* 2005; 5: 1541-1546.
- [4] Shoaib M, Bosch S, Scholten H, et al. “Towards detection of bad habits by fusing smartphone and smartwatch sensors”. In: *Proceedings of the IEEE international conference on pervasive computing and communication workshops*, St. Louis, MO, 23-27 March 2015, pp. 591-596. New York: IEEE.
- [5] Sağbas EA and Ballı S. “Estimation of human activities by using wrist movement”. In: *Proceedings of the 3rd international management information systems conference*, Izmir, 6-8 October 2016, pp. 52-58. Gölçermat Matbaacılık.
- [6] Parkka J, Ermes M, Antila K, et al. “Estimating intensity of physical activity: a comparison of wearable accelerometer and gyro sensors and 3 sensor locations”. In: *Proceedings of the 29th annual international conference of the IEEE engineering in medicine and biology society*, Lyon, 23-26 August 2007, pp. 1511-1514. New York: IEEE.
- [7] Riboni D and Bettini C. “COSAR: hybrid reasoning for context-aware activity recognition”. *Pers Ubiquit Comput* 2011; 15(3): 271-289.
- [8] B. Boashash, “Time-Frequency Signal Analysis and Processing: A Comprehensive Review”. 2015.
- [9] A. J. Campbell, M. J. Borrie, and G. F. Spears, “Risk factors for falls in a community-based prospective study of people 70 years and older,” *Journal of gerontology*, Vol. 44, No. 5, pp. M112-M117, 1989.
- [10] E. Carvalho, B. V Ferreira, C. De Souza, Y. Suhara, A. Pentland, and G. Pessin, “Driver behavior profiling : An investigation with different smartphone sensors and machine learning,” pp. 1-16, 2017.
- [11] C. Torres-huitzil and A. Alvarez-landero, “Recognition in Smartphones for Healthcare Services.”
- [12] A. S. B, B. J. Woodford, and H. Lin, “Trends and Applications in Knowledge Discovery and Data Mining,” vol. 10526, pp. 26-38, 2017.
- [13] W. Astuti, W. Sediono, A. M. Aibinu, R. Akmeliawati, and M. J. E. Salami, “Adaptive Short Time Fourier Transform (STFT) Analysis of seismic electric signal (SES): A comparison of Hamming and rectangular window,” *ISIEA 2012 - 2012 IEEE Symp. Ind. Electron. Appl.*, pp. 372-377, 2012.
- [14] Lara, O.D., Labrador, M. a., “A Survey on Human Activity Recognition using Wearable Sensors”, *IEEE Communications Surveys & Tutorials*, 15(3), p. 1192-209, (2013).
- [15] Wu, X., Kumar, V., Quinlan, J.R., Ghosh, J., Yang, Q., Motoda, H. et al. “Top 10 algorithms in data mining”, *Knowledge and Information Systems*, Springer. 14(1), p. 1-37, (2008).
- [16] Nguyễn Hà Nam, Nguyễn Trí Thành, Hà Quang Thụy, “Giáo trình khai phá dữ liệu”, Nhà xuất bản Đại học Quốc gia Hà Nội, 2016.
- [17] Breiman, L., Friedman, J., Stone, C.J., Olshen, R.A. (1984), *Classification and regression trees*, CRC press.
- [18] Breiman, L. (2001), *Random forests*, *Machine Learning*, Springer. 45(1), p. 5-32.
- [19] Dang Nhac Lu, Duc Nhan Nguyen, Thi Hau Nguyen and Ha Nam Nguyen, “Vehicle Mode and Driving Activity Detection Based on Analyzing Sensor Data of Smartphones”, *Sensors* 2018, 18, 1036.
- [20] B. O. Hjorth, “Technical contributions eeg analysis based on time domain properties,” pp. 306-310, 1970.
- [21] S. Oh, Y. Lee, and H. Kim, “A Novel EEG Feature Extraction Method Using Hjorth Parameter,” Vol. 2, No. 2, pp. 106-110, 2014.
- [22] Charikleia Chatzaki, Matthew Padiaditis, George Vavoulas and Manolis Tsiknakis, “Human Daily Activity and Fall Recognition Using a Smartphone’s Acceleration Sensor” Röcker et al. (Eds.): *ICT4AWE 2016*, CCIS 736, pp. 100-118, 2017.
- [23] Dong Y, Scisco J, Wilson M, et al. “Detecting periods of eating during free-living by tracking wrist motion”. *Biomed Health Inform* 2014; 18(4): 1253-1260.
- [24] Pedometer and step counter mobile apps: how does it work? <http://mohdaslam.com/pedometer-and-step-counter-mobile-apps-how-does-it-work/> (accessed 14 December 2017).

HUMAN DAILY ACTIVITIES RECOGNITION USING A SMARTPHONE'S ACCELERATION SENSOR

Le Hong Lam, Cao Ngoc Anh, Nguyen Hoai Nam, Nguyen Duc Nhan, Tran Thuy Binh, Nguyen Ha Nam

ABSTRACT: *Accurately human daily activities recognition is always a topic that attracts a lot of attention in research and it is however a difficult task, especially in case of large number of activities including abnormal activities such as fall. Thanks to the widespread use of smartphones, the problem of activities recognition based on data obtained from sensors on smartphones is receiving much attention. This article will examine and evaluate a pattern that identifies everyday activities including anomalous behaviors based on accelerometer sensor data of smartphones. The influence of the sliding window size and the different sets of features on the classification accuracy of each activity will also be examined and evaluated in this paper. Different sets of features are based on different domains, including time domain, frequency domain and Hjorth parameters, and combinations between them. The appropriate set of features with the best classification result will be determined. Experiments are also conducted on different classifiers including Random Forest (RF), SVM, kNN and the results obtained showed that Random Forest algorithm achieved the best recognition result.*